

张胜东

- 性别：男
- 出生年月：1991.11
- 学历：硕士研究生
- QQ：435878393
- 手机：13912998528
- Email：435878393@qq.com
- 个人主页：<https://www.zhangshengdong.com>
- Github：<https://github.com/zhangsheng377>

教育经历

江苏省南京市金陵中学 2007.9-2010.7

长春理工大学光电信息学院本科 2010.9-2014.7

- 物理系,光学专业
- 获奖情况：

2010-2011 学年 一等奖学金

2011-2012 学年 一等奖学金

2012-2013 学年 一等奖学金

2013-2014 学年 国家奖学金

校级 和 院级 优秀毕业论文

- 获证书情况：

全国蓝桥杯软件大赛全国总决赛 二等奖

全国大学生数学建模竞赛吉林赛区 二等奖

吉林省程序设计大赛(acm) 一等奖

吉林省电子设计大赛 二等奖

全国信息技术考试数据库工程师认证

全国计算机四级数据库工程师

南京邮电大学研究生 2015.9-2018.7

- 计算机技术专业

- 获奖情况：

凯易讯软件大赛全国总决赛 第 25 名
中兴软件编程大赛 决赛
黑马大赛全国总决赛 第 2 名
全国物联网设计竞赛 二等奖

- 主要项目：

- i. **卫星鉴权高并发服务器和客户端：**

使用了 **epoll,fork,socket,pipe,命名管道 FIFO** 等的服务器和客户端程序，功能是串口连接北邮的网关设备进行控制，同时接收用户的信息，若是登录信息就进行鉴权，鉴权通过就将此端口转发规则写入网关设备，同时还涉及到信道分配，流量管理，加解密通讯等。

- ii. **大气质量监测及预测系统：**

树莓派开 gpio 读取传感器并上传云端，同时有触屏显示界面；跨平台客户端从云端读取数据，并作 3d 显示；用 php 写的微信公众号服务器程序，支持查询、订阅和报警；**用 Python 写了机器学习的线性回归和在线学习，来预测第二天的空气质量。**

- iii. **水产品监控及直播系统：**

与中科院南京软件研究所合作，使用单片机连接摄像头采集视频信号，使用 EasyDarwin 推送视频流，使用拉流技术建立起流媒体管理云平台，从而实现一对多的直播效果，类似于现在的直播软件。

- iv. **黑马大赛：商品类目预测：**

题目：只给商品标题和已有分类，测试集中可能需要分到新的类。

方案：使用 **多线程jieba分词** 得到商品标题的分词向量，然后手撸的朴素贝叶斯算法，同时做了一些修改：**当一个词在某个类中出现的频率低于所设阈值时，则将该词在这类的权重置为 0，以此来避免大众词汇对于分类的干扰，提升小样本类别的识别率**；并且当分类得分低于阈值时，则新建分类，并更新矩阵。

- v. **利用视频关键帧预测中间帧：**

教研室项目：视频传输时只传关键帧，中间的补帧利用机器学习预测出。具体是将画面分割成许多 8*8 的小块，将每一块丢进神经网络计算运动向量，再将结果平滑，得到运动轨迹，从而生成中间帧。最后，提供训练好的模型和供 c++ 调用的 python 的接口给下游。

- vi. **盲人导盲项目：**

单板机放置于盲人帽子上，实时语音识别出口令后，调用摄像头拍照，开启控制信令 socket 与服务器建立会话，然后建立数据 socket，将压缩后的图片发送给服务器(**图片压缩后可以降低图片中杂项的干扰，提高对于主体的识别率**)。服务器使用 yolo 进行物体识别，对于主要物体的方位和距离进行估算，将结果以 json 格式返回给单板机。单板机接收到识别结果后，语音合成内容，播报出来。

工作经历

华为 数据通信网络协议开发部 2018.7-2020.5

- **主要项目：**

- i. 独立设计 Trunk 软件选口算法，使用分层的 avl 管理端口资源，使板级异常的主备切换耗时从原来的几百毫秒，降低至几毫秒。
- ii. 使用 bitmap 设计并完成网络协议的动态唯一标签申请及分配模块。
- iii. 对开源代码 sprintf 进行整改，成功对 va_list 底层异构所导致的异常进行定位，并做出应对方案。
- iv. 成为代码 committer，负责部门代码微重构，及代码review，并指导新员工编程；
- v. 被选拔进入软件学院进修，并成为部门第一个通过软件认证考试的人；
- vi. 日常分享技术总结，并在内网发博客 10 余篇，累计 UV 阅读量 3000 多人。

- **个人项目：**

- i. 参加科赛Kesci 的「二分类算法」提供银行精准营销解决方案比赛，取得全球100+名次，获得一张100美元AWS代金券。

华为 消费者云服务HiCloud开发部 2020.5-2021.9

在浏览器算法团队，负责NLP模型和搜索直达的排序模型。

- **主要项目：**

- i. 优质文章模型（浏览器每日精选栏目）：经bert得文章embedding(即文章的语义信息)，再拼接上文章的结构信息（段落、字数、图片数、来源、作者等，经过embedding和标准化），接上双塔网络，判断文章优质与否，以及属于哪个优质类别。
- ii. 层次文章分类模型：根据各层次分类之间天然的关联性，同时学习多个label，设计多任务的Bert模型（将一级分类网络的最后一级输出，拼上之前bert输出的embedding，再进二级分类网络，以此类推），在学习阶段就即可自动进行层次分类校准。并且，在推断时，可以获取各层分类类别的概率，采用beam search，进行有限度的扩展搜索。
- iii. 搜索直达功能的排序模型：打通FTRL模型上线，在产品诞生之初快速赋能；后切换到DCN模型，自动进行特征交叉；现转向ESMM模型，多任务，同时训练CTR 和 CVR 指标，以期真正提升CTCVR 业务指标。
- iv. 同时做过 文章地域模型、时效模型、负面文章模型、友商吹捧文章模型等，主管NLP领域的分类模型。

- **个人项目：**

- i. 编写股票监控平台。采用docker部署爬虫模块、量化指标算法模块、订阅分发模块等，各模块之间使用rabbitmq和redis，以及mongodb连接。爬虫模块爬取股票数据存入通用数据库接口（mongodb），并缓存至redis；算法模块监控rabbitmq，从而处理数据并将报警信息存入redis；订阅分发模块监控到有报警信息后主动向微信订阅用户推送；同时部署有微信服务器，完成与微信用户的交互。https://www.zhangshengdong.com/post/monitor_stock_system/

华为 NAIE AI模型与训练服务部 2021.9-至今

在用户体验团队，承担算法SE（架构师）角色，负责设计与实现电信领域用户体验相关模型。

- **主要项目：**

- 基站信号仿真大模型：输入地形各图层数据及基站位置等参数，输出地图各处基站信号强度。模型结构借鉴cv领域双流网络思想，采用白盒（可微电磁传播公式）和黑盒（大规模卷积网络）双流的思路。
- 大规模表格类数据无监督训练框架：针对电信领域数据基本为表格类无标签数据的特点，结合巧妙地特征工程，设计了以锚点和先验概率分布为约束的无监督训练框架。可直接利用无标签数据进行训练，给出用户的体验打分，同时支持小批量有标签样本（数据不出局点）的在线调优。
- 神经网络关于特征的模型自解释方法：利用模型对于特征的梯度，结合巧妙地特征工程构造出的背景样本和MSE Loss，即可计算出各用户特征输入关于模型打分结果的影响度。

麒麟特战队：

- **主要项目：**

- 负责开源项目大模型加速库 <https://gitee.com/ascend/AscendSpeed> 的调优部分，并成为该项目的committer。主要是带领团队进行大模型训练和调优方面的特性开发，并支撑客户训练大模型。多次向Megatron-LM、Megatron-DeepSpeed和PEFT库贡献代码。
- 向PEFT开源社区贡献了一个关键独立特性：分布式LoRA

<https://github.com/huggingface/peft/pull/1092> 已经在peft0.7.0版本发布：

v0.7.0: Orthogonal Fine-Tuning, Megatron support, better initialization, safetensors, and more [Latest](#)

BenjaminBossan released this last week · 17 commits to main since this release · v0.7.0 · 2665f80

Highlights

- Orthogonal Fine-Tuning (OFT): A new adapter that is similar to LoRA and shows a lot of promise for Stable Diffusion, especially with regard to controllability and compositionality. [Give it a try!](#) By [@okotaku](#) in [#1160](#)
- Support for parallel linear LoRA layers using Megatron. This should lead to a speed up when using LoRA with Megatron. By [@zhangsheng377](#) in [#1092](#)
- LoftQ provides a new method to [initialize LoRA layers](#) of quantized models. The big advantage is that the LoRA layer weights are chosen in a way to minimize the quantization error, as described here: <https://arxiv.org/abs/2310.08659>. By [@yxli2123](#) in [#1150](#).

Significant community contributions

The following contributors have made significant changes to the library over the last release:

[@zhangsheng377](#)

- Parallel linear Lora by [@zhangsheng377](#) in [#1092](#)
- Fix parallel linear lora by [@zhangsheng377](#) in [#1202](#)

<https://github.com/huggingface/peft/releases/tag/v0.7.0>

该分布式LoRA方案已达理论最优，领先于半年之后发表的S-LoRA论文。

iii. 向Accelerate开源社区贡献了一个关键独立特性：支持nvidia官方megatron的MegatronLMPlugin <https://github.com/huggingface/accelerate/pull/2501> 已经在accelerate0.31.0版本发布：

v0.31.0: Better support for sharded state dict with FSDP and Bugfixes Latest

Megatron

- Upgrade huggingface's megatron to nvidia's megatron when use MegatronLMPlugin by [@zhangsheng377](#) in #2501

<https://github.com/huggingface/accelerate/releases/tag/v0.31.0>

主导负责OpenMind生态社区分布式与训练特性的设计与开发工作，成为OpenMind套件的核心差异化竞争力，支持晨腾的社区生态发展。

Accelerate对接megatron特性同步反哺官方开源社区。

- iv. 负责我司行业大模型的微调部分。作为开源蓝军路线的领导人，提出并尝试了模拟退火、dpo、细化二三级子领域能力分类、数据平权采样、基于裁判模型的语料质量评估、重复训练波动分析、数据精细化管理方案等有效实践，并积极分享，助力红军路线成功。
- v. 负责我司自动化评测系统的设计与开发。设计打分流程，引入few-shot和cot，以及将rag引入评测系统，以此增强评测系统对于错误多样性的适应性。并且使用裁判模型作为rm奖励模型，打通dpo训练流程。

[pdf版简历](#)

本科时期的旧博客：<http://zhangshengdong29.lofter.com/view>